

控制与决策

Control and Decision

基于多分支融合嵌入式注意力特征提取的油井工况诊断

王通, 李远超, 高宪文, 王寒静

引用本文:

王通, 李远超, 高宪文, 等. 基于多分支融合嵌入式注意力特征提取的油井工况诊断[J]. *控制与决策*, 2025, 40(5): 1742-1750.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0855>

您可能感兴趣的其他文章

Articles you may be interested in

基于双分支特征融合的场景文本检测方法

A scene text detection based on dual-path feature fusion

控制与决策. 2021, 36(9): 2179-2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699-704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted attention sparse autoencoder

控制与决策. 2021, 36(10): 2442-2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

结合注意力机制的循环神经网络复述识别模型

Recurrent neural networks based paraphrase identification model combined with attention mechanism

控制与决策. 2021, 36(1): 152-158 <https://doi.org/10.13195/j.kzyjc.2019.0638>

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

基于多分支融合嵌入式注意力特征提取的油井工况诊断

王通^{1†}, 李远超¹, 高宪文², 王寒静¹

(1. 沈阳工业大学 电气工程学院, 沈阳 110870; 2. 东北大学 信息科学与工程学院, 沈阳 110819)

摘要: 针对油井示功图特征提取效果不佳导致工况诊断准确率不高的问题, 提出一种基于多分支融合嵌入式注意力特征提取的油井工况诊断方法. 首先, 为使提取的示功图隐含特征信息更加全面, 在卷积自编码器的基础上, 设计多分支、多尺度的编码器结构提取, 并融合示功图位移-载荷数据的特征信息; 其次, 为强化多分支融合后的局部特征, 设计一种嵌入式通道注意力机制, 在全局平均池化基础上, 添加全局最大池化, 使其能够同时关注示功图全局和局部特征; 同时, 为进一步增强示功图关键信息的隐含特征提取能力, 在通道挤压后, 激励之前嵌入通道注意力机制模块对挤压后的通道预先进行一次权重调整, 激励后进行权重的二次调整; 最后, 将提取的特征放入长短期记忆网络模型中进行油井工况诊断. 结果表明, 基于多分支融合嵌入式注意力特征提取的油井工况诊断方法在一定程度上改善了示功图有效特征提取能力, 提高了油井工况诊断率, 能够满足油田现场的实际需求.

关键词: 示功图; 特征提取; 工况诊断; 卷积自编码器; 注意力机制; 长短期记忆网络

中图分类号: TE933 文献标志码: A

DOI: 10.13195/j.kzyjc.2024.0855

引用格式: 王通, 李远超, 高宪文, 等. 基于多分支融合嵌入式注意力特征提取的油井工况诊断 [J]. 控制与决策, 2025, 40(5): 1742-1750.

Well condition diagnosis based on multi-branch fusion embedded attention feature extraction

WANG Tong^{1†}, LI Yuan-chao¹, GAO Xian-wen², WANG Han-jing¹

(1. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Aiming at the problem that the poor feature extraction of the oil well indicator diagram leads to the low accuracy of condition diagnosis, an oil well condition diagnosis method based on multi-branch fusion embedded attention feature extraction is proposed. Firstly, in order to make the extracted implicit feature information of the indicator diagram more comprehensive, based on the convolutional autoencoder, a multi-branch and multi-scale encoder structure is designed to extract and fuse the feature information of the displacement-load data of the indicator diagram. Then, in order to strengthen the local features after multi-branch fusion, an embedded channel attention mechanism is designed to add global maximum pooling on the basis of global average pooling, so that it can pay attention to the global and local features of the indicator diagram at the same time. Meanwhile, in order to further enhance the ability of implicit feature extraction for key information of the indicator diagram, the channel attention mechanism module is embedded after the channel squeeze and before the excitation, so that the squeezable channel is pre-adjusted with the weights once and the weights are adjusted twice after the excitation. Finally, the extracted features are put into the long short-term memory network model for well condition diagnosis. The results show that the well condition diagnosis method based on multi-branch fusion embedded attention feature extraction improves the effective feature extraction capability of the indicator diagram to a certain extent, increases the well condition diagnosis rate, and meets the actual needs of the oilfield.

Keywords: indicator diagram; feature extraction; work condition diagnosis; convolutional autoencoder; attention mechanism; long short-term memory network

0 引言

游梁式抽油机是石油生产中最常用的人工举升

设备. 在油田开采过程中, 抽油机采油泵工作在井下深处, 生产环境复杂, 及时判断游梁式抽油机采油过

收稿日期: 2024-07-17; 录用日期: 2024-10-08.

基金项目: 国家自然科学基金项目 (62173073).

[†]通信作者. E-mail: tykj_wt@126.com.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

程中的工况并做出调整,能够避免产量下降、设备损坏和油井停产等问题,最大限度地减少经济损失和隐患,提高开采过程的稳定性和生产效率^[1]。

现阶段,油田技术人员多采用示功图对油井工况进行诊断,主要由特征提取和诊断两个环节组成。传统的特征提取多是基于灰度、不变矩等方法^[2]对示功图轮廓特征进行处理,提取的工况特征不明显。随着深度学习技术在各行业的广泛应用,其在油井工况诊断领域也取得一定的效果^[3]。文献[4]设计了深层卷积神经网络提取示功图特征,实现对油井工况监测;文献[5]利用卷积神经网络算法构建了油井示功图的识别模型;文献[6]提出一种改进的胶囊神经网络模型,提高了示功图特征提取的能力。基于CNN的特征提取方法存在部分油井工况局部特征提取效果不佳的问题,导致后续油井工况诊断的准确率无法得到有效提高。卷积自编码器(CAE)是一种无监督学习方法,具备特征学习、数据重构的能力,可以很好地从输入中提取隐含特征,已被广泛应用于轴承、风电机组等特征提取领域^[7]。同时,通过对油井示功图位移-载荷数据分析可知,其形状接近于一种非平稳时序信号,可根据此数据的局部变化实现油井工况诊断工作。虽然CAE在上述各应用领域取得了一定的效果,但在油井工况特征提取过程中同样对部分工况局部特征提取效果不佳。针对CAE本身特征提取能力有限的问题,文献[8]设计一种动态卷积自编码器结构,拓宽了模型特征学习的宽度;文献[9]采用一种提取图像特征的去噪卷积自编码器结构,增强了特征表达能力;文献[10]提出一种中心损失-改进卷积自编码器的半监督故障诊断方法,取得了良好的特征提取效果。

针对现有方法对部分示功图局部特征提取效果不佳导致工况诊断准确率无法进一步提高的问题,基于油井示功图位移-载荷数据特性,本文提出一种多分支融合嵌入式注意力机制的油井工况特征提取方法。首先,为充分挖掘示功图全局和局部特征,设计一种多分支多尺度融合的特征提取方法,将不同分支提取的特征进行融合,保留示功图更多有效特征信息;其次,为避免融合特征存在大量的冗余信息,设计一种嵌入式通道注意力机制(ESE),相比于通道注意力机制(SE),ESE可实现通道二次权重调整,起到增强示功图特征信息通道权重的作用;最后,为验证提取特征的有效性,将提取的示功图特征输入至长短期记忆网络(LSTM)诊断模型中,对油井工况进行诊断。

1 问题描述

示功图为游梁式抽油机悬点处传感器采集到一个抽汲周期位移及载荷数据所构成的封闭曲线,其通过形状反映油井的不同工况,部分示功图如图1所示。如图1(a)所示为正常工况示功图,形状接近平行四边形。在实际采油过程中,油井会出现异常工况,如泵上碰图1(b)、气体影响图1(c)等。




图1 示功图

基于机器学习的油井工况诊断方法多是依据提取出示功图曲线形状特征信息进行诊断,常用的提取特征方法主要有不变矩、灰度、Freeman 链码等。这些方法在示功图提取过程中均面临部分相似工况难以区分的问题,如图2所示。可以看出传统方法在进行特征提取时,部分相似工况提取的特征值区分度不高,不利于后续工况诊断。而采用深度学习中的CNN进行特征提取效果有所改善,但其初始权重为随机生成,导致每次训练的模型输出不稳定。图3为基于CNN两次训练模型提取的泵下碰特征,图3(a)为诊断错误的泵下碰特征,图3(b)为诊断正确的泵下碰特征。这种训练不确定性可能导致特征提

取效果较差,需要设计一种可靠并有效的特征提取

方法,提高油井工况诊断性能.

2 基于多分支融合 ESE 的 CAE 特征提取

2.1 卷积自编码器

CAE 是由自编码器 (AE) 的全连接层换成卷积层和池化层演变而来,包含编码器与解码器两部分,编码过程为

$$h_k = g(W_k * Z_r + b_k). \quad (1)$$

其中: Z_r 为输入样本, W_k 和 b_k 分别为第 k 个卷积核的权值和偏置, $*$ 为卷积运算, $g(\cdot)$ 为池化函数, h_k 为第 k 个卷积核所提取的抽象特征. 解码过程为

$$\hat{Z}_r = \sum W'_k * g'(h_k) + b'_k. \quad (2)$$

其中: W'_k 和 b'_k 分别表示解码器中第 k 个卷积核的权值和偏置, $g'(\cdot)$ 表示池化函数.

2.2 多分支编码器结构

传统 CAE 编码器采用卷积神经网络结构,这种单分支结构特征提取能力有限,而多分支结构常用于学习多尺度、多视角的信息^[11]. 文献 [12] 构建了具有多个不同尺寸卷积核的一维深度卷积神经网络通道特征提取层,对机电装备故障进行诊断. 文献 [13] 提出了一种多通道一维卷积神经网络特征学习的齿轮箱故障诊断方法. 文献 [14] 提出了一种树状结构多分支超分辨率重构网络,增强特征表现能力. 为提高示功图特征提取能力,本文提出一种多分支编码器结构,如图 4 所示.




图2 相似工况示功图特征提取效果

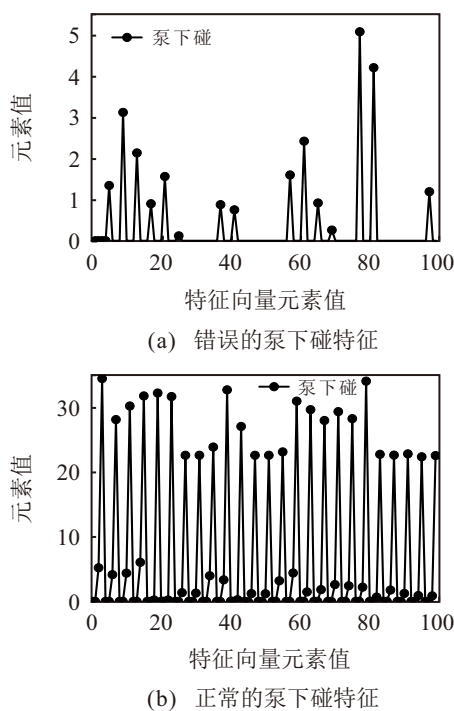


图3 CNN 特征提取效果

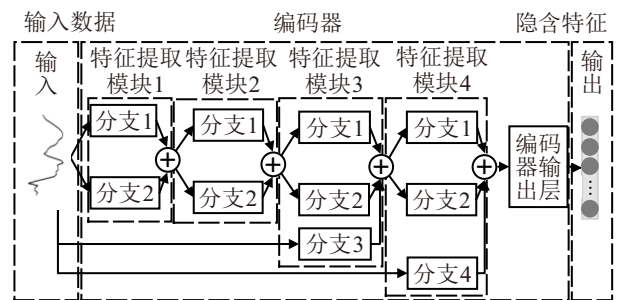


图4 多分支编码器结构

示功图二维图像由位移-载荷数据组合而成,其能完全反映油井工况特征信息,因此本文将位移-载荷一维数据作为编码器输入. 多分支编码器分为 4 层特征提取模块,每层特征提取模块包含多个分支. 首先,利用不同卷积核大小感受野不同的特性,在每层特征提取模块内设计两个不同尺度的卷积核分支 1、2,分别进行提取特征后再叠加融合,拓宽每层特征提取的尺度,避免单尺度下提取特征信息单一的问题;其次,增加两条分支 3、4,将示功图浅层特征分别与第 3 层特征提取模块、第 4 层特征提取模块的深层特征进行叠加融合,使得网络模型变得

更宽, 保留更多特征信息的同时, 避免在分支 1、2 后再添加卷积层来提升特征提取效果而造成的网络变得更深的问题; 最后, 通过输出层将多分支融合后的特征信息经一维卷积转换为输出尺寸为 36×1 的示功图隐含特征. 为更好地保留初始信号数据特征, 避免池化造成信息丢失, 实现模型鲁棒性与泛化能力的提升, 去除 CAE 中的池化层, 只保留卷积层, 卷积层激活函数均采用 LeakyReLU, 其模型结构参数如表 1 所示.

表1 多分支编码器模型结构参数

名称	模块	卷积核	步长	输入尺寸	输出尺寸
分支1	1	13	1	288×1	288×32
	2	13	2	288×32	144×32
	3	13	2	144×32	72×32
	4	13	2	72×32	36×32
分支2	1	17	1	288×1	288×32
	2	17	2	288×32	144×32
	3	17	2	144×32	72×32
	4	17	2	72×32	36×32
分支3	3	17	4	288×1	72×32
分支4	4	17	8	288×1	36×32
输出层	13	1	36×32	36×1	

2.3 嵌入式 SE 模块

由于不同分支提取的特征信息比例不同, 可能造成融合后部分通道内的局部特征不强、存在冗余信息, 此问题会对油井工况诊断造成一定影响. SE 能够调整每个通道的权重, 使得模型更关注重要通道特征, 广泛应用于行人重识别、图像分类中^[15]. SE 结构如图 5 所示.




图5 SE 结构

首先, 以 $C \times H \times W$ 为输入, $F_{sq}(\cdot)$ 为挤压操作, 由全局平均池化 (GAP) 将空间维度信息挤压为 1 的单一数值; 其次, $F_{ex}(\cdot)$ 为激励操作, 包含两个全连接层 (FC), 通过 FC 对通道特征进行学习, 得到具有通道注意力的特征图, 其维度为 $C \times 1 \times 1$; 最后, 经 $F_{scale}(\cdot)$ 将通道注意力特征图与原始特征图进行通道权重相乘, 输出具有通道注意力的特征图. 传统 SE 使用过程中存在如 FC 层参数量过大、GAP 会导致局部特征被平均等问题. 为增强多分支编码器特征提取模块有效信息的提取能力, 将 SE 运用到特征提

取模块输出端, 强化重要通道. 由于油井工况示功图既要考虑全局特征, 又要考虑局部特征, 同时因部分工况示功图局部特征不显著, 在对其特征进行全局平均池化时会导致被平均, 使得该通道加权过低, 造成局部特征丢失. 因此, 本文在文献 [16-17] 改进的基础上提出一种嵌入式通道注意力机制, 内部详细结构如图 6 所示.




图6 ESE 结构

将特征提取模块内各分支输出进行特征通道融合, 作为 ESE 结构输入, 记为 X , 特征维度为 $C \times H \times 1$.

首先, 由 GAP 和全局最大池化 (GMP) 对输入 X 各自进行挤压操作, 其中 GAP 关注示功图全局信息, GMP 关注示功图局部信息. 将挤压后的 $C \times 1 \times 1$ 特征向量, 分别经 1×1 卷积层进行“降维”, 减小模型参数量, 并进行特征学习, 特征维度变为 $C/R \times 1 \times 1$, 记为 M_{GAP} 和 M_{GMP} , 其中 $R = 8$ 为缩放系数, 公式如下:

$$M_{GAP} = \delta(\text{Conv}(\text{GAP}(X))), \quad (3)$$

$$M_{GMP} = \delta(\text{Conv}(\text{GMP}(X))). \quad (4)$$

其中: $\delta(\cdot)$ 为 ReLU 激活函数, Conv 为一维卷积层.

SE 在进行特征压缩时无法保证有效特征在后续权重调整时一定能分配到理想权重, 因此在 1×1 卷积层之后分别运用缩放系数为 2、其余结构不变的 SE 模块进行权重预调整, 保证后续再次进行权重调整时突出关注通道显著特征信息, 公式如下:

$$M'_{GAP} = F_{scale}(f_{ex}(f_{sq}(M_{GAP}), W_{GAP}), M_{GAP}, f_{ex}(f_{sq}(M_{GMP}), W_{GAP})), \quad (5)$$

$$M'_{GMP} = F_{scale}(f_{ex}(f_{sq}(M_{GAP}), W_{GMP}), M_{GMP}, f_{ex}(f_{sq}(M_{GMP}), W_{GMP})). \quad (6)$$

其中: M'_{GAP} 、 M'_{GMP} 分别为 M_{GAP} 、 M_{GMP} 经过 SE 模

块得到有权重的挤压通道; $F_{scale}(\cdot)$ 为通道数相乘运算; $f_{sq}(\cdot)$ 为挤压操作, 包含 $\delta(\cdot)$ 和 Conv; $f_{ex}(\cdot)$ 为激励操作, 包含 $\sigma(\cdot)$ 和 Conv; W_{GAP} 、 W_{GMP} 为一组学习参数, 用于建模聚合后特征所有通道之间的相关性。

然后, 将通过权重预调整的通道输入 1×1 卷积层进行通道权重再次调整, 公式如下:

$$X'_1 = \sigma(\text{Conv}(M'_{GAP})), \quad (7)$$

$$X'_2 = \sigma(\text{Conv}(M'_{GMP})). \quad (8)$$

其中: $\sigma(\cdot)$ 为 sigmoid 激活函数; X'_1 、 X'_2 分别为两条

分支得到的有权重的特征图。

最后, 将经由二次通道权重调整的两条分支输出与输入 X 相乘, 得到最终 ESE 提取的特征 \tilde{X} , 维度为 $C \times H \times W$, 公式如下:

$$\tilde{X} = F_{scale}(X'_1, X'_2, X), \quad (9)$$

其中 \tilde{X} 为 ESE 输出特性图。

2.4 基于多分支融合 ESE 的 CAE 模型结构

基于多分支融合嵌入式注意力的 CAE 模型结构由编码器和解码器组成, 如图 7 所示。

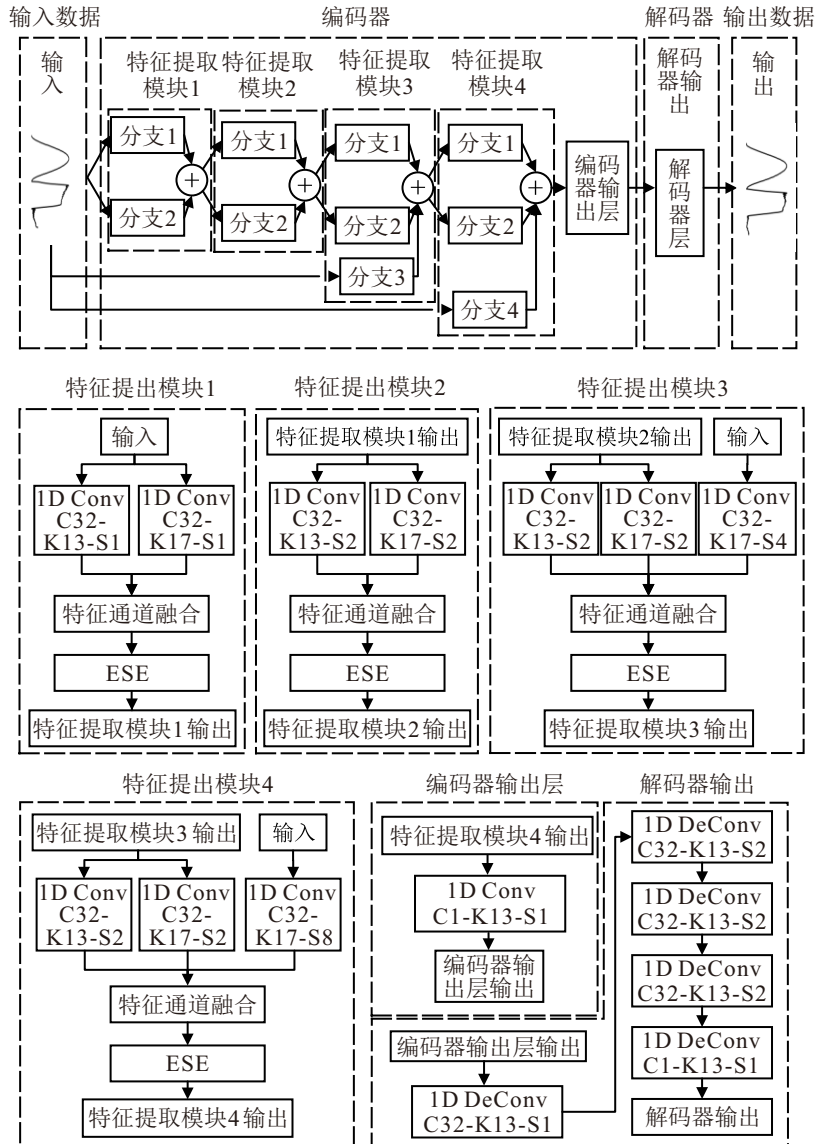


图7 基于多分支融合 ESE 的 CAE 模型结构总体框架

在多分支编码器结构基础上, 将 ESE 加入到特征通道融合之后, 利用 ESE 增强融合后局部特征提取能力, 特征提取模块输出特征经过编码器输出层进行处理, 得到一维隐含特征数据; 解码器采用单分支一维反卷积完成数据重构任务, 同样去掉池化层, 仅保留反卷积层, 避免造成信息丢失。激活函数均采用 LeakyReLU, 结构参数如表 2 所示。

表2 解码器结构参数表

名称	层序	卷积核	步长	输入尺寸	输出尺寸
解码器	1	13	1	36×1	36×32
	2	13	2	36×32	72×32
	3	13	2	72×32	144×32
	4	13	2	144×32	288×32
	5	13	1	288×32	288×1

3 基于 LSTM 的油井工况诊断模型

示功图位移-载荷数据经特征提取后得到压缩的一维数据, 类似非平稳的时间序列信号. LSTM 在处理时间序列的任务上具有效率高、网络收敛速度快等优势, 克服了循环神经网络的梯度消失和长期依赖问题^[18]. 本文 LSTM 采用单层网络结构, 含 50 个隐藏层, 输入为编码器提取的隐含特征, 输入尺寸为 1×36 , 输出为 50, FC 输入为 50, 输出为工况诊断类别标签维度.

4 仿真实验结果与分析


4.1 数据集

实验数据来源于辽河油田油井生产示功图数据, 选取 6 种示功图工况的位移-载荷数据, 尺寸为 288×1 , 分别为泵上碰、泵下碰、游动阀漏、气体影响、供液不足、正常, 每种工况类型取 100 个样本, 并按照 4: 1 的比例划分训练集和测试集.


4.2 仿真结果及分析

为验证本文提出的示功图特征提取结构的有效性, 将本文结构与多分支 CAE 模型、传统 CAE 模型进行对比. 多分支 CAE 模型编码器、解码器结构参数分别如表 1 和表 2 所示; 传统 CAE 模型编码器采用 4 层卷积、3 层池化层, 解码器采用 5 层反卷积、

3 层上采样层, 卷积核均为 13×1 . 各模型优化器均为 Adam, 损失函数为 MSE, 训练迭代次数为 100, 批次为 2; 提取的隐含特征信息尺寸为 36×1 ; LSTM 采用单层结构, 优化器为 Adam, 损失函数为交叉熵, 训练迭代次数为 200, 批次为 32.






(a) 泵上碰






(b) 泵上碰一维数据




图8 泵上碰示功图及一维数据



(a) 传统CAE编码器池化层后各模块输出



(b) 未添加ESE各提取模块输出



(c) 添加ESE各提取模块输出

图9 各 CAE 提取模型特征输出示意图

分别训练上述 CAE 模型,为更好地分析基于多分支融合嵌入式注意力 CAE 的特征提取能力,对不同的 CAE 模型结构的特征提取结果进行观测,以泵上碰示功图为例,如图 8 所示。

各 CAE 模型编码器不同特征提取模块输出位置特征如图 9 所示,其中各分图中从左到右分别是模块 2 输出、模块 3 输出和模块 4 输出。

从图 9 可以看出,添加 ESE 的多分支 CAE 在模块 4 位置输出特征最符合测试样本输入。虽然传统 CAE 能够通过增加深度在一定程度上提高其特征提取效果,但同时模型也变得更加复杂;而多分支 CAE 在同样的深度下,模块 4 输出特征较传统 CAE 更接近测试样本特征。添加 ESE 的多分支 CAE 从形态上好于未添加 ESE 的多分支 CAE,且可以在一定程度上抑制多分支 CAE 出现过拟合的现象,其提取的特征更具有代表性,性能更稳定。

为进一步验证本文提出的特征提取模型的效果,用重构示功图与原示功图数据定量对比分析,将训练好的传统 CAE、多分支 CAE 以及多分支融合 ESE 的 CAE 模型使用测试集数据进行重构。解码器重构后示功图效果如图 10 所示。

解码器重构测试指标采用 MAE、MSE,结果如表 3 所示。结合图 10 与表 3 可以看出:多分支融合 CAE 较好于 CAE 重构效果,表明多分支 CAE 相对于 CAE 具备更好的特征提取能力;多分支融合 ESE 的 CAE 重构示功图效果要好于其他模型重构效果,进一步验证了所设计的多分支融合 ESE 的 CAE 模型编码器特征提取能力较其他两种模型具备一定的优势。

表3 各模型重构测试指标

类型	训练集		测试集	
	MAE / %	MSE / %	MAE / %	MSE / %
传统CAE	1.45	0.04	1.60	0.05
多分支CAE	0.99	0.02	1.18	0.04
多分支融合ESE	0.84	0.02	1.03	0.03

为验证本文设计的特征提取模型的有效性,使用基于 3 种 CAE 模型提取到的隐含特征信息进行工况诊断,同时原实验基础上将位移-载荷原始数据直接诊断和不变矩、灰度、Freeman 链码、AE、CNN 特征提取后诊断结果加入对比。其中:AE 的编码、解码均采用 2 层全连接层,其他参数与上述各 CAE 模型保持不变;CNN 采用 6 层卷积层、6 层池化层、1 层 Flatten 层组成。为消除诊断模型对结果的影响,上述特征提取后的工况诊断算法统一采用 LSTM,

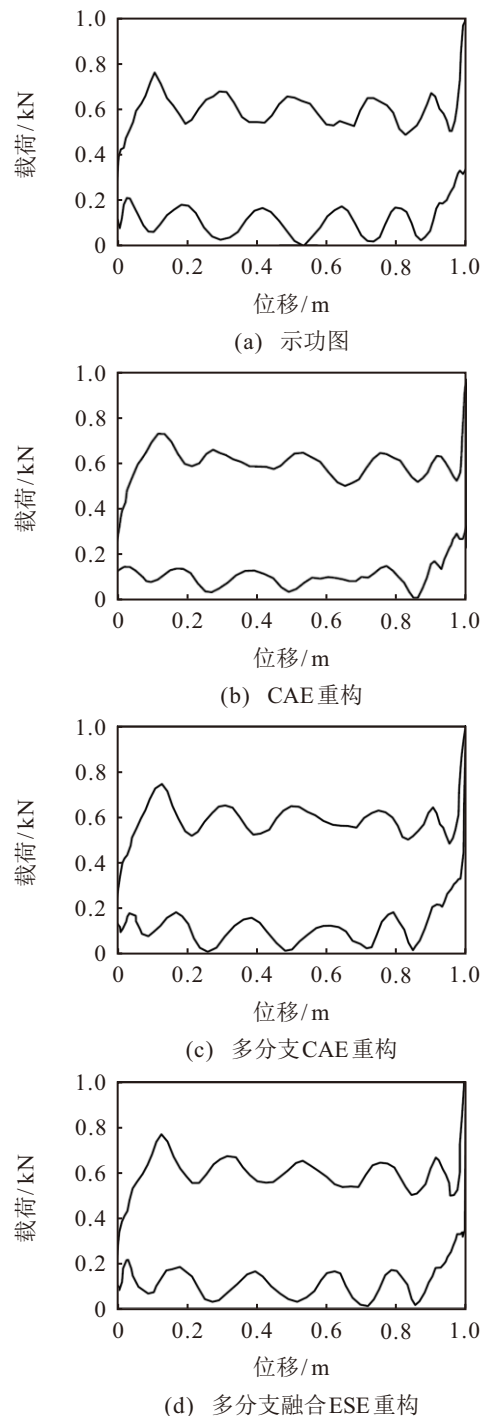


图10 模型重构示功图对比

LSTM 优化器为 Adam,损失函数为交叉熵,训练迭代次数为 200,批次为 32。训练及测试数据不变,诊断结果如图 11 所示。

为消除随机因素引起的干扰,以上实验重复 10 次,取准确率平均值评价各种方法性能,如表 4 所示。通过图 11 和表 4 可以看出:采用不变矩、灰度、Freeman 链码提取示功图特征效果不佳,导致诊断准确率不高;而深度学习模型 CNN、AE、CAE 的多层网络结构拥有更强的特征提取能力,诊断准确率较上述 3 种传统方法有明显改善。采用原始数据输入 LSTM 深度学习模型中直接诊断的平均准确率为

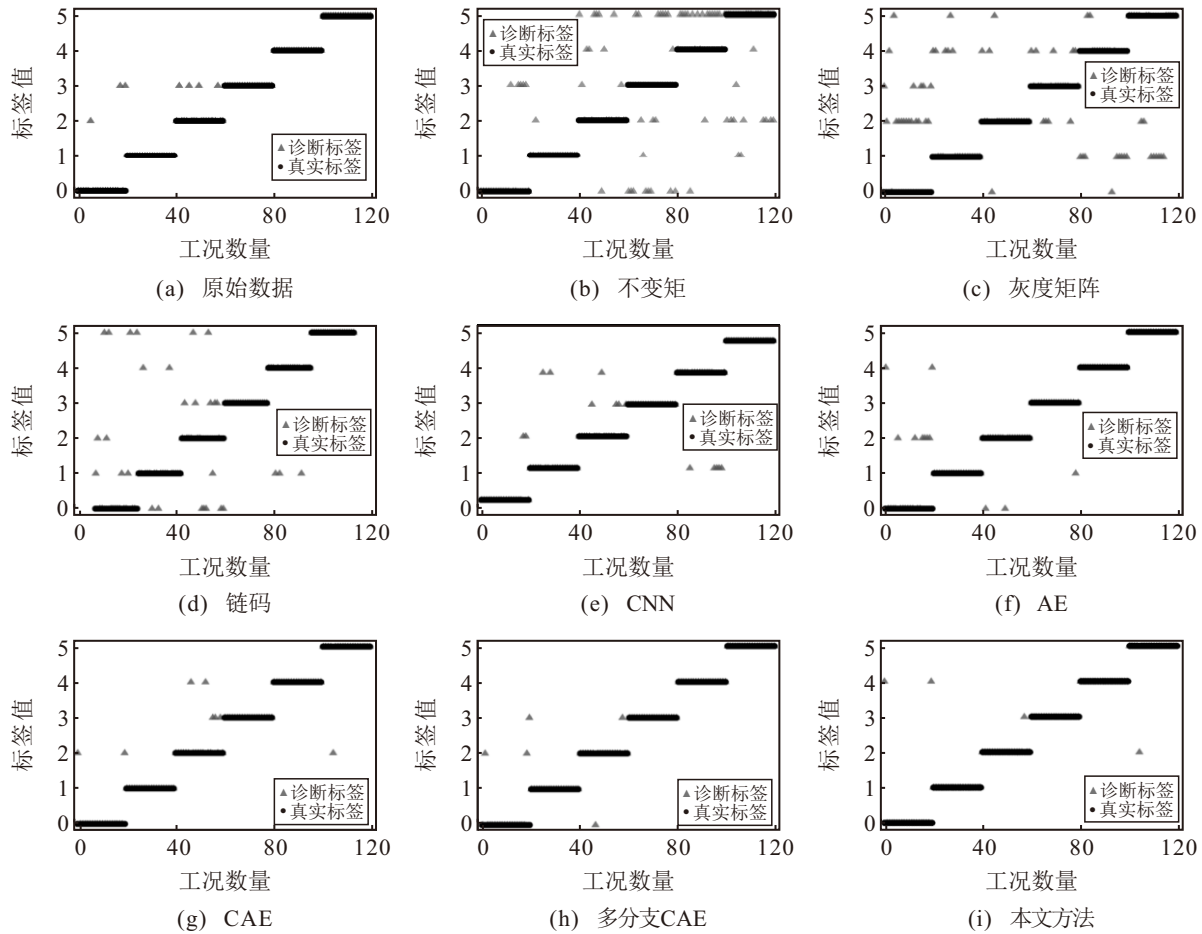


图11 不同特征提取方法诊断效果图

表4 各模型平均准确率

特征提取类型	诊断模型	平均准确率 / %	标准差 / %
原始数据	LSTM	94.382	1.314
不变矩	LSTM	45.40	4.238
灰度	LSTM	52.475	3.290
Freeman链码	LSTM	75.084	1.465
CNN	LSTM	88.113	2.142
AE	LSTM	91.250	0.559
CAE	LSTM	92.667	0.498
多分支CAE	LSTM	94.75	1.750
多分支融合ESE	LSTM	96.252	0.674

94.382 %，这表明 LSTM 本身特征提取能力与上述深度学习模型基本等同。此外，CAE 特征提取诊断效果好于 AE 模型，这表明卷积、池化层相对 FC 层具有更强的特征提取能力。基于多分支 CAE 提取特征平均诊断率为 94.75 %，验证了所设计的多分支 CAE 模型在特征提取方面有所加强，但未达到理想效果。而添加 ESE 的多分支融合 CAE 模型经多次实验平均准确率比多分支融合 CAE 模型高 1.502 %，比 CAE 模型高 3.586 %，比原始数据高 1.87 %，表明所设计的多分支融合 ESE 的 CAE 模型在一定程度上既避免了单分支 CAE 特征提取能力有限的问题，又增强了多分支 CAE 特征融合的能力，相对于上述

方法局部特征提取能力进一步提高，故障诊断准确率得到有效改善。

5 结 论

为有效提取油井工况诊断过程中示功图特征，本文提出一种基于多分支融合嵌入式注意力机制的油井示功图特征提取方法。采用多分支结构从不同尺度提取示功图特征并融合，同时采用 ESE 结构对融合后的通道权重进行再次调整。在相同解码器结构下，经重构实验，表明基于本文提出的编码器结构的 CAE 模型具有良好的重构效果和特征提取能力，对提取的特征由 LSTM 算法进行工况诊断效果最佳，表明了该方法在油井工况诊断的有效性，能够达到油田现场要求工况诊断准确率为 95 % 以上的标准。同时，所提取的示功图隐含特征相较于原示功图数据压缩较大，可以为后续油井工况长短期预测的研究提供支撑。

参考文献 (References)

[1] Cheng P, Jian Y. Application of ontology to knowledge management of sucker-rod pumping system fault diagnosis[J]. *Journal of Automation and Control Engineering*, 2013, 1(2): 126-131.
 [2] Zheng B Y, Gao X W. Sucker rod pumping diagnosis

- using valve working position and parameter optimal continuous hidden Markov model[J]. *Journal of Process Control*, 2017, 59: 1-12.
- [3] He Y P, Cheng H B, Zeng P, et al. Working condition recognition of sucker rod pumping system based on 4-segment time-frequency signature matrix and deep learning[J]. *Petroleum Science*, 2024, 21(1): 641-653.
- [4] Wang X, He Y F, Li F J, et al. A working condition diagnosis model of sucker rod pumping wells based on deep learning[J]. *SPE Production & Operations*, 2021, 36(2): 317-326.
- [5] Sun L Y, Shi H D, Bai M X. Intelligent oil well identification modelling based on deep learning and neural network[J]. *Enterprise Information Systems*, 2022, 16(2): 249-263.
- [6] 张强, 朱刘涛, 王彦琦. 基于改进胶囊神经网络的示功图诊断模型[J]. *电子科技大学学报*, 2022, 51(1): 117-122.
(Zhang Q, Zhu L T, Wang Y Q. Indicator diagram diagnosis model based on improved capsule neural network[J]. *Journal of University of Electronic Science and Technology of China*, 2022, 51(1): 117-122.)
- [7] 宋威, 林建维, 周方泽, 等. 基于改进降噪自编码器的风机轴承故障诊断方法[J]. *电力系统保护与控制*, 2022, 50(10): 61-68.
(Song W, Lin J W, Zhou F Z, et al. Wind turbine bearing fault diagnosis method based on an improved denoising AutoEncoder[J]. *Power System Protection and Control*, 2022, 50(10): 61-68.)
- [8] 高学金, 姚玉卓, 韩华云, 等. 基于注意力动态卷积自编码器的发酵过程故障监测[J]. *化工学报*, 2023, 74(6): 2503-2521.
(Gao X J, Yao Y Z, Han H Y, et al. Fault monitoring of fermentation process based on attention dynamic convolutional autoencoder[J]. *CIESC Journal*, 2023, 74(6): 2503-2521.)
- [9] Zhang H W, Liu S B, Wang C, et al. Color-patterned fabric defect detection algorithm based on triplet attention multi-scale U-shape denoising convolutional auto-encoder[J]. *The Journal of Supercomputing*, 2024, 80(4): 4451-4476.
- [10] 齐咏生, 巩育瑞, 高胜利, 等. 基于中心损失-改进卷积自编码器的滚动轴承半监督故障诊断[J]. *振动与冲击*, 2023, 42(7): 301-311.
(Qi Y S, Gong Y R, Gao S L, et al. Semi-supervised fault diagnosis of rolling bearing based on CL-ICAE[J]. *Journal of Vibration and Shock*, 2023, 42(7): 301-311.)
- [11] 范诗萌, 孙炜, 覃宇, 等. 基于三分支混合特征提取的双目立体匹配算法[J]. *机器人*, 2024, 46(4): 414-424.
(Fan S M, Sun W, Qin Y, et al. A binocular stereo matching algorithm based on three-branch hybrid feature extractor[J]. *Robot*, 2024, 46(4): 414-424.)
- [12] 卞景艺, 刘秀丽, 徐小力, 等. 基于多尺度深度卷积神经网络的故障诊断方法[J]. *振动与冲击*, 2021, 40(18): 204-211.
(Bian J Y, Liu X L, Xu X L, et al. Fault diagnosis method based on a multi-scale deep convolutional neural network[J]. *Journal of Vibration and Shock*, 2021, 40(18): 204-211.)
- [13] 张亚洲, 赵小强, 惠永永, 等. 基于多传感器数据融合的SA-DACNN齿轮箱故障诊断方法[J]. *控制与决策*, 2024, 39(11): 3699-3708.
(Zhang Y Z, Zhao X Q, Hui Y Y, et al. SA-DACNN gearbox fault diagnosis method based on multi-sensor data fusion[J]. *Control and Decision*, 2024, 39(11): 3699-3708.)
- [14] 韩玉兰, 顾琴, 崔玉杰, 等. 基于树状多分支残差注意力网络的真实场景图像超分辨率重构[J]. *控制与决策*, 2024, 39(10): 3442-3450.
(Han Y L, Gu Q, Cui Y J, et al. Real-world super-resolution based on residual attention network with tree based multi-branch structure[J]. *Control and Decision*, 2024, 39(10): 3442-3450.)
- [15] 刘建琪, 闫河, 王潇棠, 等. 改进金字塔和跳跃连接的YOLOv5目标检测网络[J]. *控制与决策*, 2023, 38(6): 1730-1736.
(Liu J Q, Yan H, Wang X T, et al. YOLOv5 object detection network with improved pyramid and skip connection[J]. *Control and Decision*, 2023, 38(6): 1730-1736.)
- [16] 李贞妮, 孙晖, 郝梓彤, 等. 一种轻量级多模态车辆轨迹预测算法[J]. *西安交通大学学报*, 2024, 58(6): 14-23.
(Li Z N, Sun H, Hao Z T, et al. A lightweight multi-modal vehicle trajectory prediction algorithm[J]. *Journal of Xi'an Jiaotong University*, 2024, 58(6): 14-23.)
- [17] 伍济钢, 文港, 杨康. 改进注意力机制的航空发动机试验转子系统智能故障诊断[J]. *振动与冲击*, 2024, 43(4): 261-269.
(Wu J G, Wen G, Yang K. Improved attention mechanism for intelligent fault diagnosis of experimental rotor systems in aero engines[J]. *Journal of Vibration and Shock*, 2024, 43(4): 261-269.)
- [18] 赵小强, 脱奔奔, 惠永永, 等. 基于ISTA-LSTM模型的间歇过程质量预测[J]. *控制与决策*, 2023, 38(11): 3279-3289.
(Zhao X Q, Tuo B B, Hui Y Y, et al. Batch process quality prediction based on ISTA-LSTM model[J]. *Control and Decision*, 2023, 38(11): 3279-3289.)

作者简介

王通 (1976-), 男, 副教授, 博士, 主要研究方向为复杂工业过程控制、检测及故障诊断, E-mail: tykj_wt@126.com;

李远超 (1998-), 男, 硕士生, 主要研究方向为故障诊断, E-mail: 2569110351@qq.com;

高宪文 (1955-), 男, 教授, 博士, 主要研究方向为复杂工业过程建模、控制与优化, E-mail: gaoxianwen@ise.neu.edu.cn;

王寒静 (2000-), 女, 硕士生, 主要研究方向为故障诊断, E-mail: 1874878919@qq.com.